

DOI:10.20079/j.issn.1001-893x.220621002

基于解调重构的跳频信号辐射源个体识别方法*

刘人玮, 查 雄, 李天昀, 章昕亮, 龚 佩

(信息工程大学 信息工程学院, 郑州 450001)

摘 要: 现有跳频信号辐射源个体识别方法大多围绕跳变瞬态的特征进行讨论, 其捕获和精准定位的难度较大。因此, 提出了一种基于解调重构的跳频信号辐射源个体识别方法, 能够有效利用跳频信号的稳态信息进行辐射源个体识别。首先对跳频信号进行跳变定时, 提取出各跳的基带波形; 然后解调出各跳的符号, 并将其经过理想成型滤波器, 得到理想的重构基带波形; 最后将原始波形和重构波形一起送入神经网络, 得到分类结果。给出发射机畸变模型和畸变参数范围, 经过多次测试给出网络参数的建议取值范围, 并进行验证实验。实验结果表明, 该方法能够有效地完成跳频信号辐射源个体识别任务。

关键词: 跳频信号; 特定辐射源识别; 解调重构

开放科学(资源服务)标识码(OSID):



微信扫码二维码
听独家语音释文
与作者在线交流
享本刊专属服务

中图分类号: TN971 文献标志码: A 文章编号: 1001-893X(2024)02-0252-09

Frequency Hopping Signal Emitter Identification Based on Demodulation and Reconstruction

LIU Renwei, ZHA Xiong, LI Tianyun, ZHANG Xinliang, GONG Pei

(Information System Engineering College, Information Engineering University, Zhengzhou 450001, China)

Abstract: Most of the existing methods for frequency hopping (FH) signal emitter identification focus on the characteristics of hopping transient time. However, the short transient time makes it difficult to capture and locate accurately. Therefore, a new method of emitter identification based on demodulation and reconstruction is proposed. This method can effectively use the steady-state information of FH signal for emitter identification. Firstly, the FH signal is timed to extract the baseband waveform of each hop. Then, the symbols of each hop are demodulated and passed through the ideal shaping filter to obtain the ideal reconstructed baseband waveform. Finally, the original waveform and the reconstructed waveform are sent to the neural network to get the classification results. The distortion model and parameters' range of the transmitter are given. After many tests, the recommended values range of network parameters are given, and the verification experiments are carried out. Experimental results show that this method can effectively complete the task of individual recognition of FH signal emitter.

Key words: FH signal; specific emitter identification (SEI); demodulation and reconstruction

0 引 言

特定辐射源识别 (Specific Emitter Identification, SEI) 是指从信号中提取出不同发射机包含的非理

想特性, 从而达到辐射源个体识别的目的^[1]。这些非理想特性来自于发射机在制造时受到工艺、环境、材料等因素的影响, 因此每个发射机难以避免地具

* 收稿日期: 2022-06-21; 修回日期: 2022-07-21
通信作者: 刘人玮 Email: 985835371@qq.com

有细微的、唯一的且难以伪造的特征,这些特征也被称为“指纹特征”。SEI 技术在军用领域的目标跟踪识别方面或者民用领域的频谱管理、无线电安全方面都有较强的现实意义和应用价值^[2]。

SEI 技术的核心是提取稳定有效的特征以保证能够做到个体识别。为此,研究者们尝试将信号映射到不同的变换域上以完成识别任务,包括功率谱^[3]、积分双谱^[4-6]、循环谱^[7]、EMD^[8-9]等。除功率谱外,其他变换域的谱图通常在高维空间中,而这样不利于特征的表示,因此需要将其降维后再提取特征,这样的作法会对发射机自身的“指纹特征”造成损失。同时,这些方法均存在一定程度的时间-频率分辨率的矛盾。

除直接在调制信号上进行数学变换外,利用解调后的 IQ 数据作为特征也是研究的一个热点。文献[10]将基带信号直接送入卷积神经网络进行识别,但是其仅对 I/Q 不平衡进行讨论,没有考虑发射机的整体结构。文献[11]将基带信号绘制成灰度矢量图后,送入卷积神经网络以完成分类任务。针对矢量图受多普勒影响较严重的问题,文献[12]将矢量图进行分解后,利用多特征融合的方法提高识别性能。

跳频通信技术具有优秀的抗干扰、抗截获和多址组网能力,在军事通信和民用移动通信中都得到了广泛的应用^[13],如 CHES 系统、SINCGARS 系列、蓝牙技术等。由于跳频信号存在诸多优点,研究人员对其从各个方面进行了研究,包括跳频系统设计^[14-16]、跳频信号检测^[17-19]、跳频参数估计^[20]、跳频信号分选^[21-27]等。其中,跳频信号分选可以分为跳频信号规格识别以及跳频信号辐射源个体识别。跳频信号规格识别^[21-24]的主要任务是在宽带中识别出不同规格的跳频信号,这些跳频信号的跳频速率、跳频图案、信号规格等往往不同,通过参数估计或者特征提取等手段,完成跳频信号分类工作。跳频信号辐射源个体识别^[25-27]是将 SEI 技术应用在跳频信号上,面对的跳频信号通常是规格相同甚至协议相同的信号,与跳频信号规格识别是互补关系。文献[25]将频率跳变瞬态特征作为跳频信号的指纹特征,使用 2.4 GHz 的 4 种蓝牙信号进行测试,取得较好的效果,但是由于该文是在电磁屏蔽环境下进行实验,因此难以验证算法在低信噪比下的鲁棒性。文献[26]以跳频信号的开机瞬态包络作为研究对象,对其多个特征构造特征集并进行识别。文献[27]将跳频信号的每个跳点拆分为上升瞬态、

稳态和下降瞬态,对这三个状态分别进行短时傅里叶变换后输入至各自的卷积神经网络中。目前,跳频信号辐射源个体识别大多集中于跳频信号的跳变瞬态,但是存在两点问题:一是在低信噪比下,信号瞬态的检测、捕获均存在难度;二是可提取的特征不多且容易受到环境影响。

针对以上问题,本文提出了一种基于解调重构的跳频信号辐射源个体识别方法。该方法不再对瞬态特征进行讨论,而是考虑使用跳频信号的稳态信息进行分类识别。本文主要工作如下:①对发射机畸变特征进行建模,并给出合适的畸变范围;②对跳频信号进行预处理,获得各个跳点的原始基带波形和理想基带波形;③设计适合以波形为输入的 Transformer,完成辐射源个体识别工作。

1 发射机畸变模型

I/Q 调制发射机的畸变模型^[11-28]如图 1 所示,包含 I/Q 不平衡畸变、等效低通滤波器畸变、相位噪声和功率放大器非线性畸变。本节将对这 4 部分模型进行介绍,同时给出较为合理的畸变参数选取原则。




图 1 I/Q 调制发射机畸变模型
Fig. 1 Distortion model of I/Q modulation transmitter

1.1 I/Q 不平衡畸变

本文将发射机中存在的 I/Q 不平衡畸变均等效为基带的 I/Q 不平衡畸变。理想 I/Q 基带信号为

$$s(t) = I(t) + jQ(t) \tag{1}$$

即 I 路与 Q 路完全正交。但是,在实际情况下,I/Q 路存在不完全正交的现象,即幅值存在偏差、相差不严格在 90°。同时,I/Q 路可能存在较小的直流分量。结合以上三种畸变,实际畸变信号可表示为

$$x(t) = (G_1 e^{j\varphi_1} I(t) + jG_0 e^{j\varphi_0} Q(t)) + (c_1 + jc_0) \tag{2}$$

式中: G_1 和 G_0 分别为 I/Q 路的增益偏差; φ_1 和 φ_0 分别为 I/Q 路的相位偏差; c_1 和 c_0 分别为 I/Q 路的直流分量。

为使上文的畸变参数能够更加直观地显示出实

际畸变情况,定义 A 为幅值不平衡系数(单位: dB), P 为相位不平衡系数(单位: $^{\circ}$), 则上文的畸变参数可以表示为, $G_1 = 10^{0.5\frac{A}{20}}$, $G_Q = 10^{-0.5\frac{A}{20}}$, $\varphi_1 = -0.5\frac{P}{180}\pi$, $\varphi_Q = 0.5\frac{P}{180}\pi$ 。

文献[29]给出了实际 I/Q 调制器正交失衡畸变范围, 文献[37]进一步缩小该范围, 将其转换为本文的畸变模型后, 可规定取值范围如下: $A \in [-1, 1]$, $P \in [-3, 3]$, $c_1, c_Q \in [-0.015, 0.015]$ 。

1.2 等效低通滤波器畸变

在发射机中可能在基带、中频及射频均存在滤波器的畸变影响, 本文将其等效为基带的低通滤波器畸变。构造滤波器畸变的频率响应^[11]为

$$H(f) = A(f) e^{j\phi(f)} \tag{3}$$

式中: 幅频响应为 $A(f) = a_0 + a_n \cos(2\pi\alpha f)$, 相频响应为 $\phi(f) = 2\pi b_0 f + b_n \sin(2\pi\beta f)$ 。通常, 线性参数 $a_0 = b_0 = 1$, 滤波器畸变体现在与幅度和时延相关的系数 α, β, a_n 和 b_n 上。本文借鉴文献[11]的畸变参数, 规定畸变参数取值如下: $\alpha = 4, \beta = 4$; $a_n \sim N(0, 0.05^2)$, $b_n \sim N(0, 0.05^2)$, $N(\cdot)$ 代表正态分布。

1.3 相位噪声

相位噪声主要由频率合成器产生。理想情况下, 频率合成器的输出为

$$s(t) = e^{j2\pi f_c t} \tag{4}$$

当存在相位噪声 $\varphi_n(t)$ 时, 带有畸变的载波信号为

$$x(t) = e^{j(2\pi f_c t + \varphi_n(t))} \tag{5}$$

如图 2 所示, 理想的载波信号应为一个单频信号, 然而实际情况中相位噪声会使得频谱泄露, 较严重的相位噪声会使星座图上的星座点在标准星座点附近振荡。




图 2 理想/实际频率源的功率谱示意图

Fig. 2 Power spectrum diagram of ideal/actual frequency source

文献[30]对锁相环的相位噪声功率谱进行了详细的介绍, 文献[31]则给出二阶锁相环的相位噪声可以建模为高斯白噪声经过一阶 Butterworth 滤波器之后的输出相位, 即

$$\varphi_n(k) + \frac{1}{2\pi B_{\text{PLL}}} \varphi_n(k-1) = n(k) \tag{6}$$

求解相位噪声的自相关函数为

$$R_{\varphi_n}(k) = \sigma_{\varphi_n}^2 e^{-2\pi B_{\text{PLL}} T_s |k|} \tag{7}$$

式中: $n(k)$ 为高斯白噪声; B_{PLL} 为环路 3 dB 等效噪声带宽; σ_{φ_n} 为相位噪声均方根值; T_s 为采样周期。可以看出, B_{PLL} 和 σ_{φ_n} 决定相位噪声大小。文献[31]说明了 σ_{φ_n} 的典型值为 $1^{\circ} \sim 3^{\circ}$, 文献[1]给出了合理的 B_{PLL} 和 σ_{φ_n} 取值, 本文规定其范围如下: $B_{\text{PLL}} \in [500, 1\,500]$ Hz, $\sigma_{\varphi_n} \in [1, 3]^{\circ}$ 。

1.4 功率放大器非线性畸变

对于窄带功率放大器, 通常使用 Taylor 级数模型描述其非线性。假设功放的输入信号为

$$s(t) = \rho(t) e^{j2\pi f_c t} \tag{8}$$

则输出信号为

$$x(t) = \sum_{k=1}^K \lambda_{2k-1} (s(t))^{2k-1} (s^*(t))^{k-1} = \lambda_1 \rho(t) e^{j2\pi f_c t} + \sum_{k=2}^K \lambda_{2k-1} |\rho(t)|^{2k} \rho(t) e^{j2\pi f_c t} \tag{9}$$

式中: $\{\lambda_1, \lambda_3, \dots, \lambda_{2K-1}\}$ 是 Taylor 级数的系数。归一化的 Taylor 级数中, $\lambda_1 = 1$, 通常 $\lambda_3 < 0$ 且 $|\lambda_k|$ 随 k 的增加而减小。

在工程上, 通常使用 IP_3 和 IP_5 来描述功放的非线性。文献[32,37]给出了 $G, \text{IP}_3, \text{IP}_5$ 和 $\lambda_1, \lambda_3, \lambda_5$ 之间的关系: $\lambda_1 = 10^{\frac{G}{20}}$, $\lambda_3 = -\frac{2}{3} 10^{-\frac{\text{IP}_3 + 3G}{10}} = -\frac{2}{3} 10^{-\frac{\text{IP}_3}{10}}$

$$\lambda_1^3, \lambda_5 = -\frac{2}{5} 10^{-\frac{\text{IP}_5 + G}{5}} = -\frac{2}{5} 10^{-\frac{\text{IP}_5}{5}} \lambda_1^5。$$

$$\text{将 Taylor 级数归一化后, 可以得到 } \lambda_1 = 1, \lambda_3 = -\frac{2}{3} 10^{-\frac{\text{IP}_3 - G}{10}}, \lambda_5 = -\frac{2}{5} 10^{-\frac{\text{IP}_5 - G}{5}}。$$

如 Analog HMC6981 放大器, 增益 $G = 26$ dB, 三阶截断点 $\text{IP}_3 = 43.5$ dBm, 可以得到 $\lambda_3 = -0.0119$ 。

文献[33]给出了 Taylor 级数的仿真值, 本文给出的 Taylor 级数取值范围为 $\lambda_3 \in [-0.03, -0.01]$, $\lambda_5 \in [-0.01, 0]$ 。

2 跳频信号预处理

不同于常规通信信号, 跳频信号单跳持续时间

短,且两跳之间存在切换时间,因此在做跳频信号辐射源个体识别前,需要进行一定的预处理。本节首先对跳频信号进行建模,然后介绍本文所需的预处理流程。

2.1 信号模型

定义跳频信号的跳频周期 T_h , 驻留时间 T_d , 信道切换时间 T_{sw} , 则有

$$T_h = T_d + T_{sw} \quad (10)$$

对于跳频信号 $s(t)$, 可将其表示为^[17]

$$s(t) = A_s \sum_k \text{rect}_{T_h}(t - T_h - t_k) e^{j2\pi f_k(t - T_h - t_k)} \quad (11)$$

式中: A_s 为跳频信号的幅度; k 表示在观测时间内的第 k 跳; t_k 表示第 k 跳的发生时刻; f_k 表示第 k 跳的载波频率; rect 为基带成型。应当注意的是, 在每跳的信道切换时间内, 没有信息传输, 即 $\text{rect} = 0$ 。

在对跳频信号进行预处理时, 假设跳频的载波频率个数 N 、载波频率集 $F = \{f_1, f_2, \dots, f_N\}$ 、单跳驻留时间 T_d 、跳频周期 T_h 为已知量。

2.2 跳变定时

跳变定时的目的是找到每跳驻留时间的起点, 可以分为 3 步, 即信道化、能量积分和检出跳点。

步骤 1 对接收到的信号 $r(t)$ 进行信道化。将 $r(t)$ 分别与频率为 $\{f_1, f_2, \dots, f_N\}$ 的各个本地载波进行下变频处理, 然后再经过低通滤波器, 得到各个信道的基带信号 $Y(t)$:

$$Y(t) = \begin{bmatrix} y_1(t) \\ y_2(t) \\ \vdots \\ y_N(t) \end{bmatrix} = \text{LPF} \left(r(t) \times \begin{bmatrix} e^{-j2\pi f_1 t} \\ e^{-j2\pi f_2 t} \\ \vdots \\ e^{-j2\pi f_N t} \end{bmatrix} \right) \quad (12)$$

步骤 2 对信道化后的各路基带信号进行能量积分。将 $Y(t)$ 中的 N 路信号取平方, 再分别进行积分得到各路短时能量 $E(t)$, 每次积分长度为 T_d 。

$$E(t) = \begin{bmatrix} e_1(t) \\ e_2(t) \\ \vdots \\ e_N(t) \end{bmatrix} = \begin{bmatrix} \int_t^{t+T_d} y_1^2(\tau) d\tau \\ \int_t^{t+T_d} y_2^2(\tau) d\tau \\ \vdots \\ \int_t^{t+T_d} y_N^2(\tau) d\tau \end{bmatrix} \quad (13)$$

步骤 3 得到最佳起点并检出跳点。将 $E(t)$ 各路相加得到整体的能量变化 $E_Y(t)$, 然后以 T_h 为间隔累加, 能量最大值点为单跳驻留时间的中点, 该点

前移 $T_d/2$ 即为第一个跳点的最佳起点 t_s , 故每跳的最佳起点为 $\{t_s, t_s + T_h, t_s + 2T_h, \dots\}$ 。根据每一路在驻留时间的能量大小, 判断出该时刻跳点出现的信道, 即检出跳点。图 3 为跳变定时示意图。




图 3 跳变定时示意图
Fig. 3 Hopping timing diagram

于是, 可以得到包含每一跳原始基带波形的信号 $y_B(t)$ 。对于第 i 跳, $t \in [t_s + (i-1)T_h, t_s + iT_h]$, 则

$$\begin{aligned} \text{ix} &= \text{index} \{ \max(e_1(t), e_2(t), \dots, e_N(t)) \} \\ y_B(t) &= y_{\text{ix}}(t) \end{aligned} \quad (14)$$

式中: index 表示为取下标操作; ix 可以理解为在该跳时间内能量最大的信道。

2.3 解调重构

为了使深度学习过程中有一定的“参考”, 本文设计将解调后的结果重构成理想基带波形 $y_1(t)$ 作

为参考波形。解调重构的过程如下:对 $y_B(t)$ 进行定时同步,解调出符号;根据调制方式和过采倍数,设定成型滤波后,得到 $y_1(t)$ 。

本文使用基于最大似然的定时估计^[34]。假设跳频信号的符号速率 R_B 已知,将每一跳基带信号视作单独的突发信号 $y_B(n), n \in [0, T_h F_s - 1]$ 。其中, F_s 为采样率,为了方便后续处理,令 F_s 是 R_B 的整数倍。可以计算出该跳的最佳采样点 $\hat{\tau}$ 为

$$\hat{\varphi}_D = \arg \left\{ \sum_{n=0}^{T_h F_s - 1} F[y_B(n)] e^{-j2\pi \frac{R_B}{F_s} n} \right\} \quad (15)$$

$$\hat{\tau} = -\frac{\hat{\varphi}_D}{2\pi R_B} \quad (16)$$

式中: $F[\cdot]$ 表示非数据辅助估计非线性变换式,本文选择较为简单的绝对值非线性算法:

$$F[y_B(n)] = |y_B(n)| \quad (17)$$

于是,该跳点的每个最佳采样点 n_k 可表示为

$$n_k = \hat{\tau} + k \frac{F_s}{R_B}, k \in [0, M-1] \quad (18)$$

同时 $n_k = m_k + \mu_k, m_k$ 是 n_k 的整数部分, μ_k 是 n_k 的小数部分,使用立方插值的 Farrow 结构插值器计算最佳采样点的值:

$$y_B(n_k) = [\mu_k^2 \mu_k 1] \cdot \begin{bmatrix} 0.5 & -0.5 & -0.5 & 0.5 \\ -0.5 & 1.5 & -0.5 & -0.5 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} y_B(m_k+2) \\ y_B(m_k+1) \\ y_B(m_k) \\ y_B(m_k-1) \end{bmatrix} \quad (19)$$

根据 $y_B(n_k)$ 的值就可以解调出符号 sym,再经过成型滤波器就可获得理想的重构基带信号 $y_1(t)$ 。

3 用于辐射源识别的 Transformer

Transformer^[35] 作为与卷积神经网络、循环神经网络不同的深度学习网络,在多个领域上取得了良好的效果,本节将介绍用于辐射源识别的 Transformer 架构。

3.1 整体结构

本文网络架构如图 4 所示,由输入端、骨干网络和输出端组成。当前,本文将重构波形作为“参考”存在,提出了应用 Transformer 编码器的辐射源个体识别网络。




图 4 网络架构示意图

Fig. 4 Network architecture diagram

3.2 输入端

输入端由嵌入层和位置编码层构成。将原始波形 $y_B(n)$ 和重构波形 $y_1(n)$ 合并后作为网络的输入。假设每跳传输 M 个符号,过采率 $\text{sps} = F_s/R_B$,则每跳的采样点数 $\text{len}_0 = M \times \text{sps}$ 。

嵌入层实际上为 1 维卷积层。嵌入层的输入通道数为 4,输出通道数设置为 $4 \times \text{sps}$,卷积核大小为 sps 。该操作意在将每个符号长度的采样点视为一个“单词”,其长度 $d_{\text{model}} = 4 \times \text{sps}$,即输出通道数。

实际上,跳变定时难以做到每次都精确到跳变处的采样点(尤其是低信噪比下),为此需要得到类似重叠滑动窗口的效果。设 s 为每次向后滑动长度占单个符号采样点数的比例(为方便叙述,后文简称为滑动比例 s),则嵌入层的步进 stride 为

$$\text{stride} = \lfloor s \times \text{sps} \rfloor \quad (20)$$

式中: $\lfloor \cdot \rfloor$ 代表向下取整。由此,可得到嵌入层输出的向量长度 len 为

$$\text{len} = \left\lfloor \frac{\text{len}_0 - \text{sps} + \text{stride}}{\text{stride}} \right\rfloor \quad (21)$$

至于位置编码,本文使用了与 Transformer 原文相同的正弦型位置编码:

$$\text{PE}(\text{pos}, 2i) = \sin(\text{pos}/10000^{2i/d_{\text{model}}}) \quad (22)$$

$$\text{PE}(\text{pos}, 2i+1) = \cos(\text{pos}/10000^{2i/d_{\text{model}}})$$

同时,输入端增加一个可学习的分类向量,长度为 d_{model} ,该向量的网络输出即为分类结果。

3.3 骨干网络

骨干网络由 Transformer 编码层组成。骨干网络的参数有编码层个数 n_{layers} , 注意力头个数 n_{heads} , 词向量长度 d_{model} 和逐位前馈网络投影维度 $dim_{feedforward}$ 。

同 Transformer, $dim_{feedforward}$ 设置为 2 048。根据多次实验,本文给出网络参数的建议取值范围:

$$\begin{cases} sps \times 4 / n_{heads} \geq 40 \\ n_{layers} \leq 5 \end{cases} \quad (23)$$

该取值范围为建议值,可以设置超出该范围的取值,但是可能会使网络较难收敛或者参数量过大而导致效果一般。同时可以看出,不建议过采率 $sps \leq 10$ 。

3.4 输出端

输出端即全连接层,输入通道数为 d_{model} ,输出

通道数为输出分类个数 $n_{classes}$ 。经过输出端后,对各类计算 softmax 以判出分类得分,进一步得出分类结果。

4 实验

本文实验条件设置如下:采样率 20 MHz;跳频信号具有 8 个载频,分别为 $[1, 2, 3, 4, 5, 6, 7, 8]$ MHz;跳速 500 hop/s;每跳总时长为 50 个符号周期,其中 5 个符号周期用于信道切换,45 个符号周期用于传输内容。无特殊说明时,符号速率 400 kBd,即 $sps = 50$;QPSK 调制。20 个辐射源,畸变参数如表 1 所示。信噪比 E_b/N_0 为 7~25 dB,步进 2 dB。每个 E_b/N_0 下,每个辐射源包含 1 000 个训练样本和 1000 个测试样本。

表 1 辐射源畸变参数
Tab. 1 Transmitter distortion parameters

辐射源	A	P	c_1	c_Q	a_n	b_n	B_{PLL}	σ_{φ_n}	λ_3	λ_5
1	0.556 3	-2.667 0	-0.004 5	-0.010 1	-0.011 7	-0.018 5	508.246 4	2.128 1	-0.018 4	-0.003 1
2	-0.808 3	2.776 3	0.009 9	0.008 8	0.037 2	0.039 1	1 189.168 1	1.801 6	-0.029 0	-0.001 2
3	0.314 6	-2.192 2	0.002 6	-0.005 7	-0.118 2	-0.057 3	972.767 9	1.428 1	-0.013 0	-0.002 2
4	-0.067 1	2.548 6	0.001 5	0.000 9	0.007 3	0.035 8	812.866 3	1.372 8	-0.028 4	-0.000 4
5	-0.341 5	1.886 2	0.012 5	-0.010 0	0.088 6	0.043 7	873.191 0	1.323 4	-0.020 3	-0.004 8
6	-0.926 2	1.222 6	-0.006 4	0.003 1	-0.046 9	0.013 4	584.367 6	1.159 1	-0.019 3	-0.001 1
7	0.563 1	-1.113 6	0.007 7	-0.007 1	0.010 8	0.079 8	528.903 3	2.358 8	-0.012 1	-0.002 4
8	-0.614 9	-2.099 6	0.007 6	0.004 6	0.042 8	-0.049 1	1 417.843 7	1.599 1	-0.022 0	-0.002 0
9	-0.365 2	1.352 5	-0.003 6	0.005 7	-0.015 1	0.022 6	921.085 4	1.087 9	-0.010 4	-0.008 5
10	0.866 9	-1.399 1	0.002 0	0.007 4	-0.041 3	0.070 6	1 094.849 4	2.577 2	-0.014 3	-0.003 6
11	0.587 2	2.004 3	-0.012 7	-0.001 5	0.051 5	-0.012 4	1 344.264 2	1.624 6	-0.027 0	-0.009 7
12	0.508 5	-1.785 4	-0.013 4	-0.012 5	-0.064 4	0.069 8	984.420 2	2.011 0	-0.021 2	-0.005 0
13	0.169 6	-1.729 1	0.000 9	-0.008 1	-0.011 9	-0.047 5	679.530 6	2.709 3	-0.024 2	-0.009 8
14	-0.742 4	1.884 3	0.008 4	0.012 4	-0.020 7	0.013 2	1 491.203 5	2.259 7	-0.020 6	-0.002 9
15	-0.194 3	-0.604 3	0.013 0	-0.010 4	0.037 9	-0.011 3	667.488 6	2.344 9	-0.027 4	-0.008 6
16	-0.245 7	-0.298 1	-0.011 1	0.009 8	-0.003 0	0.034 5	735.639 7	2.558 6	-0.011 4	-0.001 3
17	-0.749 4	-1.909 7	0.002 1	0.001 2	-0.019 8	0.034 5	1 414.976 3	2.092 0	-0.021 1	-0.009 0
18	-0.622 8	2.852 1	-0.000 9	0.014 9	0.010 2	0.055 7	1 144.258 4	2.349 8	-0.017 3	-0.002 4
19	0.164 3	-0.866 8	-0.014 6	-0.012 7	0.028 5	0.055 2	1 305.432 8	1.214 4	-0.029 8	-0.001 6
20	0.404 3	-2.590 2	-0.004 9	-0.001 7	0.077 4	-0.104 7	515.736 3	2.878 8	-0.018 8	-0.006 7

本实验使用 NVIDIA GeForce RTX 2080 Ti GPU 在 PyTorch 1.9.0 上进行,学习率为 10^{-4} ,所有模型均训练 50 轮。

4.1 分析有/无重构波形对识别准确率的影响

本文将理想的重构波形和原始波形一并输入至神经网络中,目的是使神经网络在学习发射机畸变时,能够有不受发射机畸变影响的“参考”。

图 5 展示了有/无重构波形时的网络识别准确率,网络参数统一设置为 $n_{heads} = 5, s = 0.25$ 。有重构波形的网络设置 $n_{layers} = 3$,与之对比的无重构波形的网络,一个设置相同层数进行对比,即 $n_{layers} = 3$;另一个为了平衡参数量(因为无重构波形时,输入为有重构波形时的一半,同时网络参数也减少一半),设置 $n_{layers} = 6$ 。可以看出,无论是相同层数还是相同

参数量的无重构波形网络,其识别准确率均不如重构波形时,由此可证明本方法的有效性。




图 5 有/无重构波形时的识别准确率
Fig. 5 Recognition accuracy with or without reconstructed waveform

4.2 分析网络参数对识别准确率的影响

图 6 展示了不同滑动比例 s 下的识别准确率,可以看出,采用重叠滑窗的效果会有一定提升,但是如果滑动距离过小,导致进入 Transformer 编码层的序列长度较大,效果小幅下降。因此,滑动比例 s 应该取一个适当大小的值,当单跳符号数在 $[30, 50]$ 之间时,建议滑动比例 s 取值范围为 $[0.2, 0.5]$ 。




图 6 不同滑动比例 s 下的识别准确率
Fig. 6 Recognition accuracy under different sliding ratio

图 7 和图 8 展示了不同编码层个数 n_{layers} 和注意力头个数 n_{heads} 下的准确率。整体来说,这两个参数对准确率影响不大。 n_{layers} 直接改变了网络参数量,而对于本文的畸变模型及参数而言,不需要过大的网络。训练时发现, $n_{layers}=3$ 时的网络比 $n_{layers}=4$ 或 5 时更易于收敛,在训练 50 轮时, $n_{layers}=3$ 的网络收敛情况更佳,因此其准确率稍高。 n_{heads} 不改变网络参数量,而是通过降低特征维度以使注意力学习到不同的模式。同样地,训练时发现, n_{heads} 较高会导致网络难以收敛。可以看出, $n_{heads} \geq 2$ 时的准确率相近,且略优于 $n_{heads}=1$ 。




图 7 不同编码层个数 n_{layers} 下的识别准确率
Fig. 7 Recognition accuracy under different numbers of coding layers




图 8 不同注意力头个数 n_{heads} 下的识别准确率
Fig. 8 Recognition accuracy under different numbers of attention heads

综上,验证了 3.3 节给出的网络参数建议范围的合理性。

4.3 分析过采率对识别准确率的影响

图 9 展示了不同过采率 sps 下的识别准确率,可以看出,过采率的提高对本文方法识别准确率的提高是有帮助的。造成该现象的原因可能在于更高的采样率能够刻画出更多的波形非线性特征,有利于网络的特征提取。




图 9 不同过采率下的识别准确率
Fig. 9 Recognition accuracy under different samples per symbol

4.4 分析符号个数对识别准确率的影响

对于跳频信号而言,跳速是一个重要的指标。本文方法将每一跳作为一个独立的信号,因此跳速对本文算法的直接影响不大。然而,假设信号跳速很高,可能间接导致每跳的符号个数减少。

图 10 展示了不同符号个数 $nsyms$ 下的识别准确率,可以看出,较少的符号个数可能会使识别准确率下降,但同时符号个数的持续增加不会使性能有明显提高,反而可能会在训练耗费更多的资源。因此,符号个数适中即可,在 50 倍过采条件下,建议符号个数尽量保持在 $[30,50]$ 之间即可。




图 10 不同符号个数下的识别准确率

Fig. 10 Recognition accuracy under different numbers of symbols

4.5 对比不同方法下的识别准确率

文献[11]提出了一种将矢量图送入神经网络进行辐射源识别的方法(后称矢量图方法),图 11 展示了本方法与矢量图方法的识别准确率对比。其中,矢量图方法使用 ResNet50 作为神经网络,输入使用 1 跳/5 跳产生的、大小为 224×224 的矢量图。需要说明的是,本文方法和 1 跳矢量图方法将每一跳单独视作一个单位,不需要数据辅助;而 5 跳矢量图方法由于需要进行各跳间的拼接,因此需要数据辅助(如同步字头)对每一跳进行同步以消除可能由相位模糊带来的干扰。




图 11 不同方法下的识别准确率

Fig. 11 Recognition accuracy under different methods

从图 11 可以看出,本文方法在识别准确率优于矢量图方法,原因可能在于:一是本文方法利用重构波形,使得网络更易学习到与辐射源个体相关的非线性知识;二是本文方法将波形直接输入至网络,而非矢量图是将信号转换为图片。在信号转换为图片后,导致图片上存在较多冗余信息(如矢量图中包含较多空白区域),同时可能会对信号里的信息造成损失(如信号的浮点值转换为像素值)。但是矢量图方法对 10 倍过采率的信号依然有适应性,这是该方法相比本文方法的优点所在。

5 结束语

本文提出了一种基于解调重构的跳频信号辐射源个体识别方法。该方法首先对跳频信号进行各跳的跳变定时,得到各跳的原始基带波形;然后解调出各跳的符号序列,再重构出理想波形;最后将原始波形和重构波形送入网络中,得到分类结果。实验结果表明,该方法能够有效地对 20 类辐射源进行识别,且对跳频信号较短的序列长度有适应性,不需要同步序列作为数据辅助。但是,该方法对采样率有一定要求,过采率不宜低于 10 倍,对设备要求较高。在下一步工作中,可以考虑尝试使用在嵌入层后加入全连接层提高特征维度,以降低网络对采样率的需求。

参考文献:

[1] 朱家威,李天昀,寸陈韬.一种基于相位噪声的 MIMO OFDM 辐射源个体识别方法[J].信息工程大学学报,2021,22(6):647-654.

[2] 陈浩,杨俊安,刘辉.基于深度残差适配网络的通信辐射源个体识别[J].系统工程与电子技术,2021,43(3):603-609.

[3] 王检,张邦宁,魏国峰,郭道省.基于 Welch 功率谱和卷积神经网络的通信辐射源个体识别[J].电讯技术,2021,61(10):1197-1204.

[4] 钱祖平,许渊,邵尉,等.基于高阶谱和时域分析的电台稳态特征提取算法[J].电子与信息学报,2013,35(7):1599-1605.

[5] 任东方,张涛,韩洁.基于双谱与特征选择的通信辐射源识别算法[J].信息工程大学学报,2018,19(4):410-415.

[6] DING L, WANG S, WANG F, et al. Specific emitter identification via convolutional neural networks[J]. IEEE Communications Letters, 2018, 22(12): 2591-2594.

[7] 周楷,黄赛,曾昱祺,等.基于稳态循环谱特征的通信辐射源识别方法[J].北京邮电大学学报,2021,44(3):100-105.

[8] PAN Y, YANG S, PENG H, et al. Specific emitter identification based on deep residual networks[J]. IEEE

- Access, 2019, 7: 54425–54434.
- [9] LIANG J H, HUANG Z T, LI Z W. Method of empirical mode decomposition in specific emitter identification [J]. Wireless Personal Communications, 2017, 96 (2) : 2447–2461.
- [10] WONG L J, HEADLEY W C, MICHAELS A J. Specific emitter identification using convolutional neural network-based IQ imbalance estimators [J]. IEEE Access, 2019, 7: 33544–33555.
- [11] 潘一苇, 杨司韩, 彭华, 等. 基于矢量图的特定辐射源识别方法 [J]. 电子与信息学报, 2020, 42 (4) : 941–949.
- [12] ZHA X, LI T, QIU Z, et al. A novel anti-Doppler SEI algorithm based on the vector diagram decomposition [J]. Electronics Letters, 2021, 57 (20) : 785–787.
- [13] 梅文华. 跳频通信 [M]. 北京: 国防工业出版社, 2005.
- [14] 刘明阳. 卫星通信中跳频频率合成器与跳频收发信机的研究 [D]. 南京: 东南大学, 2015.
- [15] GUO Y, XIE Z. Design of PLL frequency synthesizer in frequency hopping communication system [C] // Proceedings of 2010 International Conference on Communications and Mobile Computing. Shenzhen: IEEE, 2010: 138–141.
- [16] XU Y, ZHAO F, HU C, et al. Design of frequency synthesizer in frequency-hopping transceiver [C] // Proceedings of 2013 IEEE 10th International Conference on ASIC. Shenzhen: IEEE, 2013: 1–4.
- [17] 李硕, 李天昀. 短波信道下的跳频信号检测 [J]. 电子学报, 2019, 47 (3) : 623–629.
- [18] HU H, FAN X, LI L, et al. Detection of costas-encoding frequency-hopping signal based on suppressing power spectrum and pulse detection [C] // Proceedings of 2017 IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference. Chongqing: IEEE, 2017: 1154–1158.
- [19] LEE K G, OH S J. Detection of frequency-hopping signals with deep learning [J]. IEEE Communications Letters, 2020, 24 (5) : 1042–1046.
- [20] QI Y, LU L X, ZHANG K. Frequency-hopping period estimation based on binary-sum in frequency domain [C] // Proceedings of 2014 International Conference on Wireless Communication and Sensor Network. Wuhan: IEEE, 2014: 91–94.
- [21] 李彬, 徐怡杭, 罗杰. 采用残差神经网络的无人机遥控信号识别监测算法 [J]. 西安交通大学学报, 2021, 55 (12) : 146–154.
- [22] 史浩东, 卢虎, 卞志昂. 深度卷积网络多目标无人机信号检测方法 [J]. 空军工程大学学报 (自然科学版), 2021, 22 (4) : 29–34.
- [23] 张萌, 王文, 任俊星, 等. 基于 HOG-SVM 的跳频信号检测识别算法 [J]. 信息安全学报, 2020, 5 (3) : 62–77.
- [24] LIU P, HAN Z, SHI Z, et al. Recognition of overlapped frequency hopping signals based on fully convolutional networks [C] // Proceedings of 2021 28th International Conference on Telecommunications. London: IEEE, 2021: 1–5.
- [25] 李文龙, 陈悦, 许金勇, 等. 蓝牙通信中的射频指纹识别技术 [J]. 计算机工程, 2014, 40 (1) : 11–14+19.
- [26] 睦萍, 郭英, 张坤峰, 等. 半监督条件下的 CRC 跳频电台指纹特征识别 [J]. 系统工程与电子技术, 2019, 41 (1) : 187–193.
- [27] KANG J, SHIN Y, LEE H, et al. Radio frequency fingerprinting for frequency hopping emitter identification [J]. Applied Sciences, 2021, 11 (22) : 1–26.
- [28] HUANG Y, ZHENG H. Radio frequency fingerprinting based on the constellation errors [C] // Proceedings of 2012 18th Asia-Pacific Conference on Communications. Jeju: IEEE, 2012: 900–905.
- [29] GEORGIADIS A, KALIALAKIS C. Evaluation of error vector magnitude due to combined IQ imbalances and phase noise [J]. IET Circuits, Devices & Systems, 2014, 8 (6) : 421–426.
- [30] KIM Y W, DU YU J. Phase noise model of single loop frequency synthesizer [J]. IEEE Transactions on Broadcasting, 2008, 54 (1) : 112–119.
- [31] SRIDHARAN G. Phase noise in multi-carrier systems [M]. Toronto: University of Toronto, 2010.
- [32] WU Q, TESTA M, LARKIN R. On design of linear RF power amplifier for CDMA signals [J]. International Journal of RF and Microwave Computer, 1998, 8 (4) : 283–292.
- [33] LU J, QIN X, XU X, et al. Identification of multiple-antenna emitters using power amplifier nonlinearity [C] // Proceedings of 2020 5th International Conference on Computer and Communication Systems. Shanghai: IEEE, 2020: 691–696.
- [34] 杨小女. 同步参数高精度估计研究 [D]. 郑州: 解放军信息工程大学, 2007.
- [35] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C] // Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: IEEE, 2017: 6000–6010.
- [36] LIU C, XIAO H, WU Q, et al. Spectrum design of RF power amplifier for wireless communication systems [J]. IEEE Transactions on Consumer Electronics, 2002, 48 (1) : 72–80.
- [37] 朱家威, 李天昀, 寸陈韬. 一种基于正交失衡的 MIMO OFDM 辐射源指纹提取方法 [J]. 信息工程大学学报, 2021, 22 (5) : 530–536.

作者简介:

- 刘人玮 男, 1995 年生于辽宁铁岭, 2017 年获学士学位, 现为硕士研究生, 主要研究方向为通信信号处理。
- 查雄 男, 1995 年生于江西九江, 2020 年获硕士学位, 现为博士研究生, 主要研究方向为通信信号处理。
- 李天昀 男, 1979 年生于江西萍乡, 2011 年获博士学位, 现为副教授, 主要研究方向为通信信号处理、软件无线电。
- 章昕亮 男, 1998 年生于江苏盐城, 2020 年获学士学位, 现为硕士研究生, 主要研究方向为通信信号处理。
- 龚佩 女, 1998 年生于江西九江, 2020 年获学士学位, 现为硕士研究生, 主要研究方向为通信信号处理。